

딥 러닝 기반의 가짜 얼굴 검출

(Deep Learning Based Fake Face Detection)

김 대 희¹⁾, 최 승 완²⁾, 곽 수 영³⁾*

(Kim DaeHee, Choi SeungWan, and Kwak SooYeong)

요 약 최근 바이오인식 기술이 대중화됨에 따라 위·변조에 대응하는 연구 및 시도들이 많이 진행되고 있다. 본 논문에서 인공지능으로 만든 합성된 얼굴을 진짜 얼굴인지 합성된 가짜 얼굴인지를 판별하는 방법을 제안하고자 한다. 제안하는 알고리즘은 크게 2가지 단계로 구성되어 있다. 먼저, 실제 얼굴 사진에 여러 가지 GAN(Generative Adversarial Networks) 알고리즘을 통해 합성된 가짜 얼굴을 생성하게 된다. 이후, 실제 얼굴 영상과 생성된 얼굴 영상을 딥러닝 알고리즘에 입력하여 진짜 또는 가짜인지 판별하도록 한다. 제안한 알고리즘은 실제 육안으로도 구별하기 어려운 합성 영상도 잘 구분하고, 테스트 결과 88.7%의 정확도를 확인하였다.

핵심주제어 : 가짜 얼굴, GAN, 딥러닝

Abstract Recently, the increasing interest of biometric systems has led to the creation of many researches of biometrics forgery. In order to solve this forgery problem, this paper proposes a method of determining whether a synthesized face made of artificial intelligence is real face or fake face. The proposed algorithm consists of two steps. Firstly, we create the fake face images using various GAN (Generative Adversarial Networks) algorithms. After that, deep learning algorithm can classify the real face image and the generated face image. The experimental results shows that the proposed algorithm can detect the fake face image which looks like the real face. Also, we obtained the classification accuracy of 88.7%.

Key Words : Fake Face, GAN, Deep Learning

1. 서 론

정보통신의 발달로 개인 보안 기술은 급속도로 발전하고 있다. 현재 사회에서 가장 많이 사용되고 있는 PIN(Personal Identification Number)의 패스워드 방식은 분실이나 도용, 암기 등 여러 가지 단점이 존재하고 있다. 이러한 문제를 해소하기 위해 바이오인식 기술이 발전하게 되었으며 최근 바이오인식 기술은 다양한 분야에 적용하려는 연구가 진행되고 있고, 실제 적용하고 있다. 바이오인식은 사람에 대해 측정 가능한 신

* Corresponding Author : sykwak@hanbat.ac.kr

+ 이 논문은 정부(미래창조과학부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임 (NRF- 2015R1C1A1A02037299)

Manuscript received September 11, 2018 / revised October 10, 2018 / accepted October 15, 2018

1) 한밭대학교 제어계측공학과, 제1저자

2) 한밭대학교 제어계측공학과, 제2저자

3) 한밭대학교 전자제어공학과, 교신저자

체적, 행동적 특성을 추출하여 본인 여부를 비교, 확인하는 기술을 말한다. 신체정보 및 행동정보에는 지문 인식, 홍채 인식, 망막 인식, 손 모양, 음성 인식, 안면 인식 등의 방법이 있다. 이러한 특징은 분실할 우려가 없으며, 암기하지 않아도 되는 장점이 있다. 하지만 바이오인식기술이 발전하는 만큼 위·변조에 따르는 가짜 데이터에 대한 보안 취약점이 발견되고 있고, 가짜 데이터를 생성하는 기술의 발전은 가짜 데이터에 대한 보안 취약점을 심화 시키고 있다.

최근 GAN(Generative Adversarial Network)[1] 알고리즘을 이용한 가짜 데이터 생성 기술이 이슈화 되고 있다. 2017년 Nvidia에서 유명한 20만 명의 사진을 학습시켜 실존하지 않는 사람의 얼굴을 무한히 만들 수 있는 GAN기술을 선보였으며[2], 이는 실제 육안으로도 구별하기 어려울 만큼 정교한 기술이다. 또한, 미국 워싱턴대학교 연구진은 미국의 전 대통령 버락오바마의 사진을 학습시켜 가짜 연설 동영상을 만들어 내는 기술을 발표하였다[3]. 이처럼 생성된 가짜 데이터가 사람의 육안으로 구별하기 어려울 정도로 발전함에 따라 실제 영상과 가짜 영상을 구별할 수 있는 기술이 요구되고 있다.

현재까지 가짜 영상을 구별하는 연구로는 연속된 이미지를 분석하여 눈의 움직임에 대한 차이를 비교하는 방법[4]과 고주파 성분의 에너지 비율을 계산하여 분류하는 방법[5]이 있지만 딥러닝을 적용한 연구는 시작 단계에 불과하다. 따라서 본 논문에서는 GAN의 기법을 이용하여 만들어진 가짜 얼굴 데이터와 진짜 얼굴 데이터를 CNN(Convolution Neural Network)구조를 이용하여 학습한 후 가짜 얼굴과 진짜 얼굴을 구별할 수 있도록 하고, 적용한 결과를 분석해 보고자 한다.

2. 선행연구

2.1 GAN(Generative Adversarial Networks)

GAN은 2014년 구글브레인의 Ian Goodfellow에 의해 처음으로 제안된 생성적 적대신경망 모델이다. 비 지도학습 기반의 학습 모델이며, 생성

자(Generator)와 판별자(Discriminator) 모델로 구성되어 있다. 두 모델은 상반된 목적을 갖고 있다. 판별자는 실제 데이터를 학습하고 이를 바탕으로 생성자는 가짜 데이터를 생성한다. 진짜 데이터에 가까운 가짜 데이터를 생성하는 것이 목적이다. 판별자는 입력된 데이터를 가짜 데이터인지 진짜 데이터인지 판별한다. 생성자는 판별자를 속이지 못한 데이터를 학습하고, 판별자는 생성자에게 속았던 데이터를 학습한다. 이러한 과정을 반복할수록 생성자는 진짜에 가까운 가짜 데이터를 생성할 수 있다.

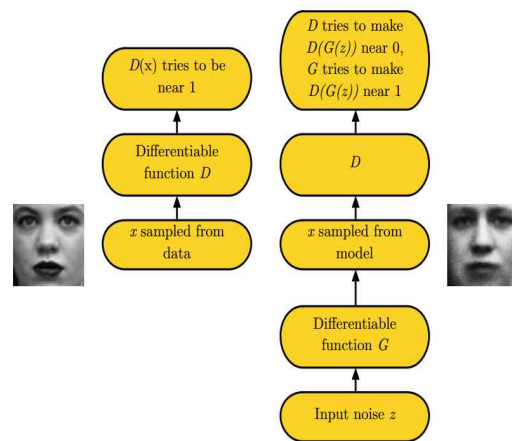


Fig. 1 Generative Adversarial Network Frame[1]

Fig. 1은 [1] GAN의 흐름도를 나타내며 x 는 입력 원본, z 는 입력 노이즈, D 는 판별자, G 는 생성자를 의미한다. $D(x)$ 는 판별자가 입력 x 를 원본인지 가짜 인지를 판별하는 확률이다. 진짜 이미지에서 뽑은 입력 x 는 $D(x) = 1$ 이 되도록 노력하고, G 에서 임의의 노이즈 z 를 이용하여 만들어진 가짜 이미지 $G(z)$ 에 대해서는 $D(G(z)) = 0$ 이 되도록 노력한다. 즉, 판별자는 실수할 확률을 낮추기 위해 노력하고, 반대로 $D(G(z)) = 1$ 이 되도록 노력한다. 즉, 생성자는 판별자가 입력이 x 인지 $G(z)$ 인지 구분 못하도록 $G(z)$ 를 x 에 가깝게 생성하도록 노력하고 판별자는 그럼에도 불구하고 원본과 가짜를 분류해 낼 수 있도록 학습한다. 따라서 이러한 모델을 수식으로 표현하면 수식(1)과 같은 $V(G, D)$ 에

대한 미니맥스 문제를 푸는 것으로 각각의 모델의 성능이 향상된다.

$$\min_D \max_G V(D, G) = E_{x \sim P_{data}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))]$$

수식 (1)

아래의 Fig. 2에서[1] 각각 점선이 의미하는 뜻은 검은 점선은 데이터 분포, 파란 점선은 판별자 분포, 녹색선이 데이터 생성 분포이다. 아래의 x 와 z 선은 각각의 영역을 나타내며, 화살표는 $G(z)$ 의 매핑을 뜻한다. 초기 (a)의 P_{data} 와 P_g 의 분포가 서로 다르지만 D 모델이 두 개의 분포를 구별하기 위해 학습을 하면 (b)처럼 어느 정도 완만해져 구분할 수 있을 정도로 변하게 되고, 이후에 G 모델을 학습이 되면 (c)와 같이 P_{data} 와 P_g 가 점점 가까워지게 된다. 이러한 단계를 계속 반복하다 보면 결국에는 (d)와 같이 $P_{data} = P_g$ 가 되어 D 모델이 원본과 가짜를 판별하지 못하는 확률 50%로 유지된다.




Fig. 2 Generative Adversarial Network Frame[1].

2.2 DCGAN(Deep Convolution Generative Adversarial Network)

GAN의 최대 단점으로는 생성자와 판별자 사이의 불균형으로 인한 불안정성으로 꼽는다. 이러한 단점을 다양한 접근으로 해결을 시도하였으며, 이를 극복하고자 DCGAN이 제시되었다[6].




Fig. 3 DCGAN Architecture[6]

DCGAN의 구조는 Fig. 3과[6] 같은 구조를 가지고 있으며 기존 GAN과의 차이점은 이름에서 볼 수 있듯이 심층 신경망이 적용되었다. 기존의 완전 연결 계층들은 다중 컨볼루션 층으로 대체되었다. DCGAN의 판별자는 일반 CNN 구조에서 사용되는 스트라이드 컨볼루션(Sprided Convolution)방식이다. 이는 CNN 구조에서 특징을 추출하고 분류하는 부분을 담당한다. 생성자의 필터는 원본 이미지의 특징을 복원할 수 있도록 학습된다. 입력 노이즈 z 를 이용하여 z 의 분포 위치에 대응하는 이미지를 생성하게 된다. 입력 노이즈 z 에 대한 산술 연산을 시행하면 최대한 z 와 매핑되는 이미지를 생성하게 된다. 그 과정에서 각각의 컨볼루션 필터들이 학습 이미지의 특징적인 부분들을 기억하기 때문에 벡터 산술연산이 가능하게 된다. 마치 word2vec[7]과 같이 학습된 생성자가 벡터 산술 연산이 가능하다. 즉, Fig. 4와[3] 같이 각각의 입력 데이터에 대하여 부분별로 특징점을 추출하여 조합하게 된다.

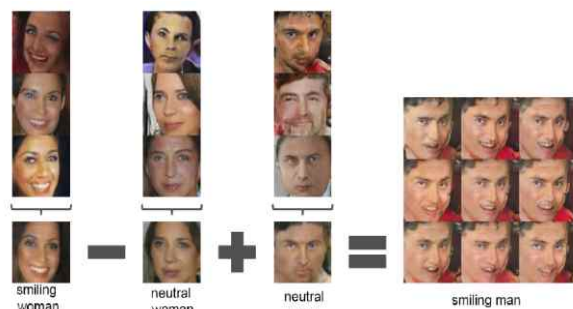


Fig. 4 z Vector Arithmetic[6]

2.3 BEGAN(Boundary Equilibrium Generative Adversarial Network)

BEGAN[8]은 DCGAN과 마찬가지로 GAN의 종류 중 하나이며 입력 데이터와는 전혀 다른 이미지를 생성하는 DCGAN과는 다르게 BEGAN은 입력 데이터와 최대한 비슷하게 이미지를 생성한다. 그 이유는 BEGAN의 구조상 오토엔코더(Auto-Encoder)[9] 방식을 사용하기 때문이다. 입력 데이터와 비슷한 이미지를 생성하는 이유는 오토엔코더 방식은 Fig. 5와[8] 같은 구조에서 항등함수의 근사를 학습하기 때문이다. 즉, 자기 자신을 목적으로 사용하기 때문에 자기 비지도 학습으로 분류된다. 아래 Fig. 5는 BEGAN의 구조를 나타낸다.

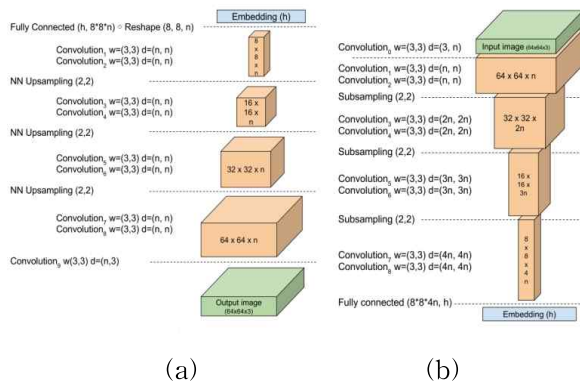


Fig. 5 BEGAN Architecture

- (a)Generator/Decoder,
- (b)Discriminator/Auto-Encoder[8]

BEGAN은 데이터 분포가 아닌 손실 분포에 더 집중한다. 즉, 샘플의 분포를 직접적으로 일치시키려고 하는 대신 오류의 분포를 일치시키는 것이 특징이다. 픽셀 관점의 손실들이 서로 독립할 때, 이미지 관점의 손실은 정규분포를 따른다고 근사 할 수 있다. 손실함수가 독립동일분포일 경우 중앙극한정리에 의해 손실함수는 정상분포가 된다는 것이 확인 가능하다. 손실함수를 수식으로 정리하면 수식(2)와 같다.

$$L(v) = |v - D(v)|^\eta$$

where $\begin{cases} D: R^{N_x} \rightarrow R^{N_x} \text{ is the autoencoder function.} \\ \eta \in 1, 2 \text{ is the target norm.} \\ v \in R^{N_x} \text{ is a sample of dimension.} \end{cases}$

수식 (2)

3. 제안하는 방법

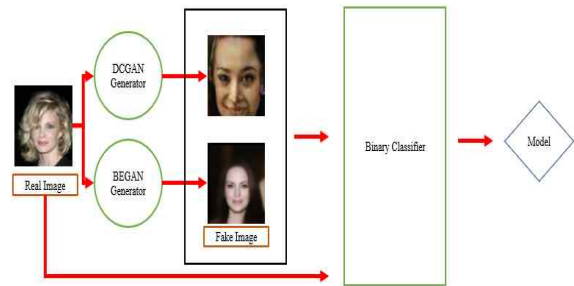


Fig. 6 The Overall Flowchart of the Proposed Methods

본 논문에서 제안하는 방법의 전체적인 흐름은 위의 Fig. 6의 흐름도와 같다. 먼저 수집된 진짜 얼굴 데이터를 이용해 DCGAN과 BEGAN의 판별기와 생성기를 학습하여 가짜 얼굴 데이터를 생성한다. 이때 DCGAN, BEGAN 두 가지 종류의 GAN을 이용하는 이유는 GAN의 네트워크 구조에 따라 생성되는 가짜 데이터의 특성이 다르기 때문이다.

먼저 DCGAN은 새로운 이미지를 생성하기 때문에 기존에 존재하지 않았던 인물의 얼굴을 생성할 수 있으며 비교적 선명한 해상도의 얼굴 데이터를 생성할 수 있다는 특성이 있다. 하지만 DCGAN은 해상도는 높지만 부자연스러운 얼굴 모양의 이미지를 생성하기도 하는 단점이 있다.

반면, BEGAN은 오토엔코더 방법을 기반으로 새로운 이미지를 생성하기 때문에 입력된 얼굴 데이터에 최대한 근접하여 새로운 얼굴 데이터를 생성한다. 따라서 DCGAN과는 다르게 기존의 데이터를 모방하는 데이터가 생성되며, DCGAN보다 자연스러운 얼굴데이터가 생성된다는 특성이

있다. 하지만 BEGAN은 픽셀 단위로 데이터를 생성하기 때문에 DCGAN에 비해 낮은 해상도의 얼굴 데이터를 생성한다. 이처럼 각각의 GAN의 특성에 따라 다양한 형태의 가짜 데이터 생성이 가능하다. 따라서 데이터의 다양성을 갖추기 위하여 다른 특성을 갖는 두 가지 종류의 GAN을 사용하여 가짜 얼굴 데이터를 생성 하였다. 아래의 Fig. 7은 DCGAN과 BEGAN으로 생성된 가짜 얼굴 데이터이다.

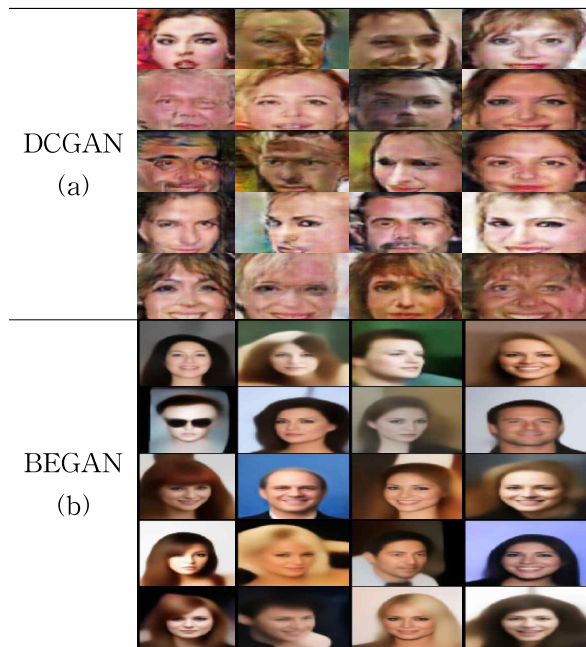


Fig. 7 Fake Image Created by GAN
(a)DCGAN, (b)BEGAN

다음 단계는 본 논문에서 제안하는 CNN구조의 이진분류기를 학습 시키는 단계이다. 학습단계에서 가장 먼저 해야 할 것은 학습 데이터를 어떻게 구성 하느냐에 따라 분류기의 성능이 달라지기 때문에 학습데이터를 어떻게 구성할 것인지를 정해 주는 것이다. 본 논문에서는 GAN을 이용하여 가짜 데이터를 생성 할 때 사용되는 학습데이터의 양, 학습 시간 등 학습 환경에 따라 생성되는 데이터의 품질이 다르기 때문에 학습 환경에 따른 데이터 품질차이에 초점을 두고 데이터의 품질을 상, 중, 하 단계로 나누어 학습 데이터를 구성하였다. Table 1과 Table 2는 학습

환경을 다르게 하였을 때 DCGAN과 BEGAN을 통해 생성되는 가짜 얼굴 데이터의 결과를 나타내고 있다.

Table 1 Step by Step Learning Result(DCGAN)




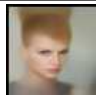
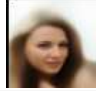

	Number of Data	Learning Time	Result
하	25,000	6h	
중	50,000	12h	
상	100,000	24h	

Table 2 Step by Step Learning Result(BEGAN)

	Number of Data	Learning Time	Result
하	25,000	6h	
중	50,000	12h	
상	100,000	24h	

위와 같이 학습에 필요한 데이터를 구성 하였으면, 본 논문에서 제안하는 CNN 구조의 이진분류기를 학습 하여 가짜 얼굴과 진짜 얼굴을 구분할 수 있는 모델을 생성한다.

본 논문에서 제안하는 이진분류기의 구조는 Fig. 8과 같으며 입력으로는 64x64x3의 입력 데이터를 받고, 6개의 컨볼루션층(Convolution Layer)과 1개의 완전연결층(Fully Connection Layer), 총 7개의 층으로 이루어져있다. 각각의 컨볼루션층의 파라미터로 커널의 크기는 3X3으로 입력하였고, 컨볼루션 필터의 수는 32, 64, 128, 256, 512를 주었다. 입력 데이터는 6개의 컨볼루션층을 거치면서 여러 가지 형태의 특징(Feature)들이 검출되며 이러한 특징들은 완전연

결층을 통해 4096개의 벡터로 출력되어 나타난다. 중간 레이어에서 사용된 활성화 함수는 렐루(ReLU) 함수다. 중간 레이어에서 시그모이드(Sigmoid) 함수를 사용하면 임계값을 넘는 순간 값을 변화시키지만 렐루 함수는 입력을 그대로 넘겨주어 0이 아니면 양수 값이 출력됨으로 기울기 값이 사라지는 문제를 해결하였다.




Fig. 8 Proposed CNN Architecture.

다음으로 위의 CNN구조로 학습되어 최종적으로 얻어진 모델을 이용하여 새로 입력받은 데이터가 진짜 얼굴데이터 인지 가짜 얼굴데이터인지를 구별한다. CNN구조에 학습 시키는 과정 중 최종 완전 연결층에서의 활성화함수를 시그모이드 함수를 사용하여 최종 결과로 입력 사진이 가짜 얼굴 데이터일 확률로써 나타나게 된다. 따라서 최종 결과로 나온 확률이 50% 이상 이면 가짜 얼굴데이터로 판단하고 50% 미만 이면 진짜 얼굴데이터로 판단한다.

4. 실험 및 평가

실험은 논문에서 제안한 CNN구조의 이진분류기 학습에 사용된 데이터와 파라메타 변화에 따른 결과를 비교 실험하여 학습에 관한 경향을 실험 하였다.

실험에 사용된 프로그램 언어는 Python으로 진행하였으며, 학습 도구는 Keras 오픈 소스 신경망 라이브러리를 이용하여 진행하였다. 또한 실험을 진행한 컴퓨터 사양은 CPU i7-7700K, GPU Geforce GTX1060 8GB, RAM 8GB의 사양

을 갖추어 실험을 진행 하였다.

학습데이터 구성에는 학습에 필요한 학습데이터(Input Data), 검증용 하기위한 검증데이터(Validation Data), 최종모델의 성능을 평가할 때 사용하는 테스트데이터(Test Data)로 나뉜다. 이때 사용한 진짜 얼굴데이터는 오픈 데이터셋인 Large-Scale CelebFaces Attributes (CelebA) Dataset[10]을 사용하였고 해상도는 224X224로 사용하였다. 가짜 얼굴데이터는 앞에서 생성한 DCGAN과 BEGAN 데이터를 이용하였다. 가짜 얼굴데이터 또한 오픈 데이터셋[10]을 이용하여 생성하였다.

학습데이터와 검증데이터의 비율에 대한 성능을 실험하기 위해 입력데이터와 검증데이터의 비율을 조절하여 실험을 진행 하였다. 실험 결과 Table 3 와 같은 결과를 보여 줬고, 검증데이터의 비율에 따라 정확도가 증가하는 경향을 확인 했다. 학습을 진행하고 더 많은 검증데이터로 검증하기 때문에 검증데이터가 많아질수록 정확도가 증가하는 것은 당연한 결과이다. 하지만 실험 결과 6만장의 검증데이터를 사용 하였을 때와 10만장의 검증데이터를 사용 하였을 때 비슷하게 높은 정확도를 보여주고 있지만 검증데이터가 10만장일 때 에는 과적합(Overfitting) 문제가 발생하여 실제사용 하기엔 부족한 모델이 생성되었다. 따라서 학습데이터와 검증데이터의 비율을 적절하게 정하여 학습을 진행 하여야 한다.

추가적으로 학습에 사용된 파라미터의 변화에 따른 결과도 실험할 필요가 있다. Table 4는 입력데이터와 학습 횟수(Epoch) 비율에 대한 실험 결과를 보여준다. 학습 횟수 비율을 높여서 학습을 진행하였을 경우에 학습 횟수 비율이 낮을 때 보다는 높지만 학습 횟수 비율이 과도하게 높을 경우에는 과적합 문제로 인해 오히려 정확도가 더 낮게 출력되는 것을 확인할 수 있다. 이 경우에도 마찬가지로 과적합 문제를 발생하지 않게 적절한 학습 횟수를 정하여 학습을 진행 하여야 한다. 따라서 제안한 CNN구조와 위의 경향 중 가장 적합하다고 판단한 비율을 이용해 학습을 진행하였다. 그 결과 Fig. 9의 그래프 결과와 같이 검증 데이터에 대해서 99.80%의 높은 정확도를 보였다.

Table 3 Correlation between Input Data and Validation Data

Data	Validation Accuracy
Input-200,000 Validation-600	68.1 %
Input-200,000 Validation-6,000	83.7 %
Input-200,000 Validation-60,000	99.8 %
Input-200,000 Validation-100,000	99.99 %

Table 4 Correlation between Input Data and Validation Data

Data	Validation Accuracy
Input-200,000 Epoch-10	98.9 %
Input-200,000 Epoch-20	99.8 %
Input-200,000 Epoch-30	99.6 %




Fig. 9 Learning Process

또한 학습시킨 모델의 정확한 성능을 확인하기 위해 ROC곡선의 하단면적 AUROC(Area under the ROC Curve)를 계산하여 모델의 정확도를 평가 하였다. 평가에 사용된 테스트데이터는 진

짜 얼굴데이터 200장, 가짜 얼굴데이터 200장을 테스트 데이터로 이용하였다. 테스트 데이터 역시 학습 데이터와 마찬가지로 상, 중, 하 단계의 데이터를 구성하였다. Fig. 10은 테스트 데이터의 일부이다.



Fig. 10 Test Dataset
(a) Real Image, (b) Fake Image

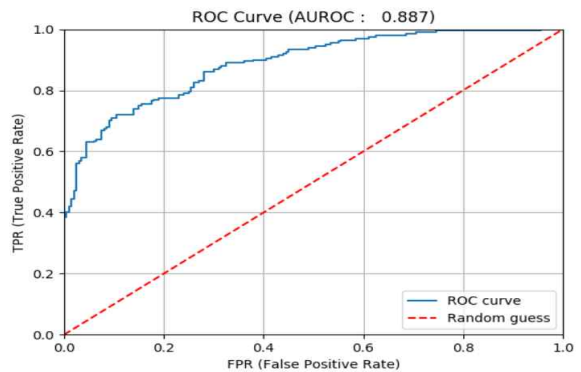


Fig. 11 Learning Process

테스트 데이터를 바탕으로 모델의 정확도를 확인해 본 결과 88.7%라는 결과를 확인하였다.

5. 결론 및 향후 연구방향

본 논문에서는 발전하고 있는 딥러닝 기술 이면에 있는 문제점을 보완하고자 하였고, 그 중에서도 가짜 얼굴데이터와 진짜 얼굴데이터를 구분하는 CNN구조의 이진분류기를 제안 하였다. 여러 가지 방법의 성능 실험을 거쳐 결과적으로 진짜 얼굴데이터와 가짜 얼굴데이터를 충분히 구분할 수 있는 수준의 결과를 테스트를 거쳐 도출하였다. 하지만 지금 이 순간에도 가짜데이터를 생성하는 기술은 발전하고 있으며, 새로운 특성을 갖는 데이터가 생성되고 있다. 따라서 이진분류기를 학습시키는데 필요한 학습데이터를 구성하는데 있어 새로운 특성을 갖는 가짜데이터의 대한 데이터도 포함 시켜야할 필요가 있다. 따라서 향후에는 기존의 데이터구성보다 조금 더 다양한 특성을 갖는 생성이미지를 학습데이터의 구성을 통하여 조금 더 정확한 검출률을 보일 수 있는 연구를 수행하고자 한다.

References

- [1] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. C. Courville and Y. Bengio., "Generative Adversarial Nets," In Proceedings of NIPS, pp. 2672 - 2680, 2014.
- [2] T. Karras, T. Aila S. Laine, J. Lehtinen., "Progressive Growing Of Gans For Improved Quality, Stability, And Variation," Published as a Conference Paper at ICLR, 2018.
- [3] Supasorn Suwajanakorn, Steven M. Seitz and Ira Kemelmacher-Shlizerman., "Synthesizing Obama: Learning Lip Sync from Audio," Published University of Washington.
- [4] J. Li, Y. Wang, T. Tan and A. K. Jain., "Live Face Detection Based on the Analysis of Fourier Spectra," In Biometric Technology for Human Identification, SPIE Vol. 5404, pp. 295-303, 2004.
- [5] S. Lin, P. Gang and Zhaohui Wu., "Blinking-Based Live Face Detection Using Conditional Random Fields," Proc, AIB, pp. 252-260, 2007.
- [6] Alec Radford, Luke Metz, Soumith Chintala., "Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks," arXiv preprint arXiv:1511.06434, 2015.
- [7] Yoav Goldberg, Omer Levy., "Word2vec Explained: Deriving Mikolov et al.'s Negative-Sampling Word-Embedding Method," arXiv preprint arXiv:1402.3722, 2014.
- [8] David Berthelot, Thomas Schumm, Luke Metz., "BEGAN: Boundary Equilibrium Generative Adversarial Networks," arXiv preprint arXiv:1703.10717, 2017.
- [9] Diederik P Kingma, Max Welling., "Auto-encoding Variational Bayes," arXiv preprint arXiv:1312.6114, 2013.
- [10] Ziwei Liu, Ping Luo, Xiaogang Wang, Xiaoou Tang., "Large-Scale CelebFaces Attributes (CelebA) Dataset," Retrived from <http://mmlab.ie.cuhk.edu.hk/projects/CelebA.html>.
- [11] Andrew NG. "Autoencoders and Sparsity", Retrieved from http://ufldl.stanford.edu/wiki/index.php/Autoencoders_and_Sparsity.
- [12] Ian Goodfellow. "Nips 2016 Tutorial: Generative Adversarial Networks," arXiv preprint arXiv:1701.00160, 2016.



김 대 희 (Kim DaeHee)

- 학생회원
- 2018년 3월-현재 : 한밭대학교
제어계측공학과
- 관심분야 : 영상처리, 컴퓨터
비전 및 그래픽스



최 승 완 (Choi SeungWan)

- 학생회원
- 2018년 3월-현재 : 한밭대학교
제어계측공학과
- 관심분야 : 영상처리, 컴퓨터
비전, 지능형자동차



곽 수 영 (Kwak SooYeong)

- 정회원
- 2010년 2월 : 연세대학교 컴퓨터
과학과 공학박사
- 2010년 3월-2011년 1월 : 삼성
전자 영상디스플레이사업부 책임

연구원

- 2011년 2월-현재 : 한밭대학교 전자제어공학과
부교수
- 관심분야 : 영상처리, 컴퓨터비전, 지능형시스템